



**Inspección Automatizada de impresión 3D**

**Juan Nicolas Gómez Novoa  
Juan Sebastián Montiel Solano**

**Proyecto de grado**

**Carvajal Diaz Luisa Fernanda**

**Bogotá D.C  
2024**

## Contenido

Resumen ejecutivo.....	3
Introducción.....	3
Objetivo general.....	4
Objetivos Específicos.....	4
Problema de investigación.....	5
Justificación.....	5
Análisis de requerimientos .....	6
Marco Teórico.....	7
Análisis de restricciones.....	12
Metodología.....	14
Análisis de costos .....	17
Análisis de resultados .....	19
Conclusiones .....	20
Referencias.....	21

## Resumen ejecutivo

Con este proyecto se tiene como objetivo principal desarrollar un sistema que se basa en visión artificial y redes neuronales, el cual permita la detección de errores al momento de ejecutar una impresión 3D. En los últimos años la impresión 3D ha tenido un auge en términos de popularidad debido a dos principales factores: el desarrollar o diseñar objetivos complejos en su construcción y el bajo costo que esto representa, aunque enfrenta desafíos importantes que se relacionan con la detección de errores en el momento de la impresión, estos errores son grietas, porosidades, deformaciones y falta de adhesión entre capas.

Este sistema busca explorar terrenos como las redes neuronales convolucionales y el aprendizaje profundo, con esto superar los retos que conlleva una inspección manual y llevando la impresión 3D a un nuevo nivel de confiabilidad y precisión. Para llevar a cabo este proyecto a continuación se mencionarán aspectos clave para alcanzar dicho objetivo.

- 1) **Problema claro:** Los errores en piezas hechas por impresión 3D al momento de su fabricación.
- 2) **Solución planteada:** Un sistema automatizado que detecte a tiempo dichos errores de fabricación
- 3) **Beneficios:** Reducción de costos, reducción de tiempos de fabricación y la eliminación de lo inspección manual constante.
- 4) **Método:** Redes convolucionales e inteligencia artificial.

## Introducción

La impresión 3D se ha consolidado en los últimos años como una tecnología que logro cambiar la fabricación moderna de algunos procesos, esto permitiendo nuevas oportunidades en una amplia variedad de sectores, desde la manufactura tradicional hasta sectores como la construcción, la medicina y la industria aeroespacial, pero, esto ¿por qué? Se debe principalmente a la alta capacidad para producir estructuras complejas con gran precisión, esto permitiendo la fabricación de piezas complejas a costos relativamente bajos.

El proceso de impresión 3D se basa en la creación de objetos tridimensionales mediante la adición gradual de capas de material tales como el plástico, la resina o metal, estas se rigen según un diseño previamente modelado. Esto permite al usuario una gran libertad tanto en el diseño como en la posibilidad de crear formas que serían muy complejas con otras técnicas de fabricación tradicional.

En el ámbito de la construcción, la impresión 3D ha permitido la fabricación de estructuras y edificios completos, dando ventajas en términos de reducción de residuos, tiempo, costos, y

dando la capacidad de diseñar formas innovadoras. En el ámbito médico, esta técnica ha revolucionado la producción de prótesis e implantes, dando precisión y bajos costos de producción.

A pesar de sus ventajas, la calidad de las piezas se puede ver afectada por fallos que se presenta durante el proceso de fabricación. La detección temprana de dichos defectos es un desafío grande, ya que los métodos de inspección manual son muy propensos a errores humanos, esto llevando a procesos ineficientes y poco confiables.

Para abordar este reto, la combinación de la visión artificial con técnicas de aprendizaje profundo ha sido una solución prometedora. Estas tecnologías permiten ejecutar inspecciones automatizadas con gran tasa de precisión, detectando defectos en tiempo real, asegurando así la calidad de las piezas fabricadas. Este informe se centra en la implementación de diversos algoritmos y técnicas avanzadas, como redes neuronales convolucionales, redes neuronales siamesas y máquinas de soporte vectorial, que han mostrado ser eficaces en la detección de fallos en piezas fabricadas mediante impresión 3D.

### **Objetivo general**

Desarrollar un sistema basado en visión artificial para identificar defectos en piezas manufacturadas realizadas en impresión 3D

### **Objetivos**

#### **Específicos**

- Evaluar las distintas técnicas y algoritmos de visión artificial que pueden ser implementados para la detección de defectos en piezas producidas mediante impresión 3D.
- Diseñar la arquitectura y los componentes clave que conformarán el sistema de visión artificial destinado a la identificación de defectos en piezas impresas en 3D.
- Analizar el desempeño esperado del sistema propuesto, considerando tanto la precisión como la eficiencia en la detección de imperfecciones en piezas impresas mediante tecnología 3D. }

## **Problema de investigación**

La impresión 3D ha sido toda una sensación en varios sectores por su capacidad para fabricar piezas personalizadas y de mayor complejidad, dando como resultado una alta precisión y por ende confiabilidad. Esta técnica de fabricación ha influenciado a varias industrias como la medicina, la automotriz, la aeroespacial y la construcción, permitiendo la creación de componentes con geometrías complejas que no serían factibles con métodos convencionales (Bhandarkar, 2023). Sin embargo, dichos beneficios se ven afectados por diferentes fallos que se presentan a la hora de la fabricación de las piezas. Estos defectos pueden ser grietas, porosidades, deformaciones, falta de adhesión entre capas y otros problemas estructurales que afectan a la funcionalidad de dicha pieza, también puede llevar a costosos elevados por tener que volver a fabricar o incluso a la inutilización completa de la pieza (Metrology,2023).

La inspección manual de este proceso de fabricación es tedioso y sobre todo susceptible a errores humanos, sobre todo cuando se habla de producción a gran escala donde se necesita alta confiabilidad y rapidez en la fabricación.

Viendo estas dificultades es muy claro la necesidad de una inspección que permita la rápida detección de errores en tiempo real y que a su vez se integre de manera sencilla en los flujos de trabajo actuales, para de esta manera no comprometer la productividad (Adv.Manuf,2022).

## **Justificación**

La inspección manual de piezas impresas en 3D presenta varias limitaciones que afectan directamente a la calidad y eficiencia del proceso de fabricación. Aunque puede ser visto como un método sencillo, la inspección manual puede tener una alta tasa de defectos, alcanzando un 80% de precisión en el mejor de los casos (Instrumental, 2020), esto sin tener en cuenta la habilidad individual de la persona, lo que introduce factores como la fatiga acumulada (Instrumental, 2020). Esto puede llevar a un aumento en los costos de producción debido a los incrementos en los tiempos de entrega por la re-fabricación y correcciones.

La visión artificial se ha visto como una solución viable, mejorando casi todos los aspectos tales como eficiencia, calidad y confiabilidad en la detección de defectos (Ren et al., 2022). Esta alternativa permite la automatización del proceso de inspección, lo que no solo ayuda a

la precisión, sino que también quita el factor de la dependencia de la mano de obra humana, de esta manera minimizando los errores.

Estos sistemas de visión artificial son capaces de interpretar datos visuales en tiempo real, lo que les permite detectar defectos que pueden ser invisibles al ojo humano, asegurando así un control de calidad mucho más riguroso. (Flexible Vision, 2023).

Además, estudios recientes han demostrado que dichos sistemas bien implementados pueden alcanzar una precisión de hasta el 100% en la clasificación de defectos, incluso con conjuntos de datos de entrenamiento relativamente pequeños y con requisitos computacionales mínimos (Singh & Desai, 2023). Esto es un detalle fundamental para las empresas que cuentan con recursos limitados, les permite implementar estos sistemas sin la necesidad de invertir en infraestructura ni capacitaciones costosas. (Singh & Desai, 2023)

## **Análisis de requerimientos**

### **Requerimientos Funcionales**

El sistema tiene que ser capaz de detectar los defectos en tiempo real, dichos defectos incluyen: porosidades, deformaciones, temperatura de la cama y falta de adhesión entre las distintas capas. Aparte de esto, debe funcionar de manera autónoma, desde el proceso de captura de imagen hasta interpretar la falla que se presenta.

Para una mayor amabilidad con el usuario final, se busca que la interfaz sea amigable, esto facilitara el proceso y la adaptabilidad al sistema, ayudando a la compatibilidad del proceso existente con el sistema.

### **Requerimientos No Funcionales**

El sistema debe contar principalmente con dos claves que son precisión y escalabilidad, al tener una precisión alta se asegura eficiencia en el proceso de fabricación lo cual conlleva a mantener costos y tiempos. A su vez debe ser escalable dependiendo el volumen de la fabricación y la cantidad de información para procesar, esto por supuesto va de la mano con la seguridad de la información ya sea por temas de patentes en las piezas o por pérdida de esta.

## **Hardware y Software**

En este caso y dadas las circunstancias específicas del proyecto, se utilizará el siguiente equipo para dar cumplimiento a los objetivos iniciales, aunque cabe aclarar que este equipo de software y hardware se puede mejorar para mayor precisión y confiabilidad.

Software: Cámara con enlace a Windows, Gpu rtx 3060, Impresora 3d Bambu Lab x1, sensor temperatura DTH22, Arduino uno.

Hardware: Tensorflow, Open Cv, Anaconda, Laabellmg, Visual Studio, Api Telegram, Pyqt5

## **Marco Teórico**

La impresión 3D ha transformado la manufactura moderna, facilitando la creación de estructuras complejas con un nivel de precisión y personalización sin precedentes. No obstante, este avance técnico enfrenta retos, especialmente en cuanto a la calidad del producto final. Como mencionan Lopez-Carreño et al. (2023) y la Universidad Distrital Francisco José de Caldas (2023), la aparición de defectos como grietas, porosidades y deformaciones en las piezas impresas es un problema frecuente que exige soluciones innovadoras para su detección y prevención.

En este sentido, la visión artificial, apoyada por técnicas avanzadas de aprendizaje profundo, surge como una alternativa prometedora para superar las limitaciones de los métodos tradicionales de inspección manual. Esta combinación entre visión computacional e inteligencia artificial ofrece una oportunidad para mejorar considerablemente tanto la precisión como la eficiencia en la detección de imperfecciones en productos fabricados mediante impresión 3D.

La visión artificial es una tecnología que permite a los sistemas informáticos interpretar y entender imágenes del entorno real. Este campo ha progresado notablemente gracias a los

avances en algoritmos de procesamiento de imágenes y reconocimiento de patrones. Según Cognex (2024), la visión artificial se utiliza en diversas aplicaciones industriales y comerciales, incluyendo manufactura, inspección de calidad, medicina y seguridad. En el sector de manufactura, por ejemplo, los sistemas de visión artificial pueden identificar defectos en productos durante la producción, mejorando la eficiencia y reduciendo el desperdicio. En medicina, estos sistemas ayudan a interpretar imágenes médicas, facilitando diagnósticos más precisos y rápidos. La capacidad de estos sistemas para procesar grandes volúmenes de datos visuales en tiempo real es clave para su éxito en estas aplicaciones. Además, el artículo de SciELO sobre "Imagen y poder en la era de la visión artificial" analiza cómo esta tecnología está impactando diversas industrias y su efecto en la sociedad (SciELO, 2021). También se aplica en la agricultura de precisión, donde cámaras y sensores permiten monitorear el estado de los cultivos y detectar plagas y enfermedades, optimizando el uso de recursos y mejorando los resultados.

El aprendizaje profundo es una rama del aprendizaje automático que utiliza redes neuronales para modelar y resolver problemas complejos. Esta tecnología, inspirada en la estructura y funcionamiento del cerebro humano, permite que las máquinas aprendan de grandes volúmenes de datos. IBM destaca que el aprendizaje profundo ha revolucionado diversos campos, incluyendo el reconocimiento de voz, la traducción automática, la detección de fraudes y la conducción autónoma. En reconocimiento de voz, los modelos de aprendizaje profundo pueden transcribir conversaciones en tiempo real con precisión, mejorando la accesibilidad y la interacción humano-computadora. En conducción autónoma, estos modelos analizan datos de sensores y cámaras para tomar decisiones de navegación seguras. El artículo de SciELO sobre "El aprendizaje profundo como herramienta para cambio en la visión de aprendizaje de una cultura escolar" examina cómo esta tecnología está influyendo en la educación y en la formación de nuevos profesionales (IBM, 2024). Además, el aprendizaje profundo se utiliza en el diagnóstico médico, donde modelos entrenados con grandes cantidades de datos de imágenes médicas pueden detectar enfermedades como el cáncer con una precisión similar a la de médicos especializados.

Los frameworks de GPU son herramientas esenciales para desarrollar y entrenar modelos de aprendizaje profundo. Las GPUs pueden realizar cálculos complejos en paralelo, acelerando

significativamente el entrenamiento de modelos. NVIDIA Developer menciona que frameworks como TensorFlow y PyTorch aprovechan las GPUs para manejar grandes volúmenes de datos y realizar cálculos matemáticos intensivos eficientemente. Estos frameworks ofrecen bibliotecas y herramientas que simplifican el desarrollo, implementación y evaluación de modelos de aprendizaje profundo. El artículo de Springer sobre "HGP4CNN: un framework eficiente de paralelización para el entrenamiento de redes neuronales convolucionales en GPUs modernas" describe cómo estos frameworks optimizan el rendimiento y el uso de recursos (NVIDIA Developer, 2024). Además, permiten crear modelos más complejos y profundos que pueden resolver problemas más intrincados en menos tiempo, esencial para aplicaciones en tiempo real como la conducción autónoma y la vigilancia.

El software para modelos de aprendizaje profundo incluye herramientas como TensorFlow, PyTorch y Keras, entre otros. Estas plataformas ofrecen los recursos y capacidades necesarias para desarrollar, entrenar y desplegar modelos de aprendizaje profundo. Geekflare señala que TensorFlow es ampliamente utilizado por su robustez y capacidad para manejar tareas complejas en entornos de producción, mientras que PyTorch se valora por su enfoque en la investigación y experimentación, facilitando la creación y prueba de nuevos modelos. Keras, una biblioteca de alto nivel para redes neuronales que se integra con TensorFlow, facilita la creación de modelos de aprendizaje profundo con una sintaxis sencilla. El artículo de SciELO sobre "Los enfoques de aprendizaje" aborda cómo estas herramientas están revolucionando el aprendizaje automático y la inteligencia artificial (Geekflare, 2024). Además, otros softwares como Caffé y MXNet también son populares en la comunidad investigadora por su flexibilidad y rendimiento. Estos softwares ofrecen entornos integrados que facilitan la depuración, el ajuste de hiperparámetros y la visualización de resultados, aspectos esenciales para el desarrollo y la implementación eficaz de modelos de aprendizaje profundo en aplicaciones del mundo real.

## **Inspección Manual vs. Visión Artificial**

### **Limitaciones de la Inspección Manual**

La inspección manual de piezas impresas en 3D tiene diversas limitaciones que afectan su efectividad en entornos de producción modernos. Gibson, Rosen & Stucker (2015) mencionan que este método tradicional puede resultar en altas tasas de defectos no detectados, con una precisión que rara vez supera el 80%. Además, como indica Yao Junwei (2022), el proceso es intrínsecamente lento, costoso y depende en gran medida de la habilidad del operador, lo que puede causar inconsistencias y errores debido a la fatiga.

Serna, Martínez, & Tamayo (2019) destacan que estas limitaciones refuerzan la necesidad de implementar sistemas automatizados que aumenten la precisión y eficiencia de la inspección, superando las limitaciones humanas y ofreciendo un proceso más confiable.

### **Ventajas de la Inspección Automatizada**

En cambio, los sistemas de visión artificial ofrecen una solución más robusta y confiable. Ren et al. (2022) afirman que estos sistemas no solo mejoran la eficiencia y calidad en la detección de defectos, sino que también reducen notablemente la dependencia de la mano de obra humana. Hurtado-Cortés, Villarreal-López, & Villarreal-López (2016) añaden que una de las principales ventajas de estos sistemas es su capacidad para interpretar datos visuales en tiempo real, lo que permite detectar defectos invisibles al ojo humano. Esta capacidad es especialmente valiosa en industrias donde la precisión y fiabilidad son fundamentales, como la aeroespacial y la médica.

### **Algoritmos y Técnicas en Visión Artificial**

La implementación efectiva de sistemas de visión artificial para la detección de defectos en impresión 3D depende de varios algoritmos y técnicas avanzadas:

- Redes Neuronales Convolucionales (CNN): Krizhevsky, Sutskever & Hinton (2012) demostraron la efectividad de las CNN en tareas de reconocimiento de imágenes, sentando las bases para su aplicación en la detección de defectos en piezas impresas en 3D. Estas redes han mostrado una gran capacidad para identificar imperfecciones con alta precisión, superando las limitaciones de la inspección manual y ofreciendo una solución escalable.

- Redes Neuronales Siamesas: Fierro y Yanai (2019) exploraron el uso de redes neuronales siamesas para tareas de recuperación de imágenes, demostrando su utilidad en comparación y reconocimiento de patrones. En impresión 3D, estas arquitecturas pueden adaptarse para comparar piezas fabricadas con modelos ideales, facilitando la detección de discrepancias indicativas de defectos.

- Máquinas de Soporte Vectorial (SVM) y Clustering: Singh et al. (2023) mostraron la eficacia de combinar SVM y técnicas de clustering para identificar defectos internos en piezas de aleación de titanio. Estos métodos han demostrado ser precisos y confiables para clasificar y agrupar diferentes tipos de imperfecciones, complementando la capacidad de las redes neuronales en la detección de defectos.

### **Aplicaciones en la Industria de la Impresión 3D**

La integración de sistemas de visión artificial en procesos de impresión 3D no solo mejora la detección de defectos, sino que permite un monitoreo más preciso y en tiempo real del proceso de manufactura, lo que asegura mayor eficiencia y control de la calidad del producto final. Bordekar et al. (2023) propusieron un enfoque de inteligencia artificial explicable para la detección de defectos en piezas fabricadas mediante manufactura aditiva, usando imágenes de tomografía computarizada para identificar posibles fallos.

En Colombia, la impresión 3D ha comenzado a desempeñar un papel clave en sectores como la construcción y la medicina, donde se ha utilizado para crear prótesis personalizadas y componentes complejos para proyectos arquitectónicos, destacando su potencial transformador en diversas aplicaciones.

### **Desafíos y Perspectivas Futuras**

A pesar de sus muchas ventajas, la implementación de sistemas de visión artificial en impresión 3D enfrenta desafíos significativos. Bordekar et al. (2023) destacan la importancia de utilizar algoritmos de aprendizaje automático bien entrenados y explicables para asegurar precisión y fiabilidad en la detección de defectos. Li et al. (2022) sugieren que desarrollar algoritmos más avanzados y mejorar las técnicas de procesamiento de imágenes

### **Análisis de restricciones**

#### **Restricciones Ambientales**

Cuando nos referimos al impacto ambiental que este método de fabricación puede llegar a presentar se debe tener en cuenta varios puntos, empezando por el tipo de material que se está manejando, esto junto al consumo de energía que la fabricación conlleva. La mayoría de los polímeros que se suelen trabajar en la industria suelen venir de los derivados del petróleo, esto afecta directamente a su manejo y reciclaje, lo cual deriva a la contaminación de suelos y cuerpos de agua. Si hablamos de metales, ocurre algo particular por la generación de polvo y partículas que pueden llegar a ser un riesgo ambiental. (McAlister & Smith, 2022).

Para mitigar y/o minimizar el impacto negativo se debe incorporar el uso de materiales biodegradables o reciclables, junto a esto implementar fuentes de energías renovables.

### **Restricciones Económicas**

La implementación de esta tecnología puede a corto plazo representar una inversión significativa si se trata de un volumen de producción significativo. Dicha inversión incluye temas como equipos, software y capacitación. Sin embargo, los beneficios ya anteriormente mencionados a lo largo del documento indican una mejora en la fabricación, mayor confiabilidad y reducción de costos por pérdidas en las piezas defectuosas (Watson, 2022).

### **Restricciones Legales**

Específicamente una ley para regular esta tecnología o método de fabricación no hay por el momento, pero si existen ya unas que regulan el tema de propiedad intelectual (Ley 23 de 1982 y Decisión Andina 351 de 1993), esta protege el diseño y uso de terceros no autorizados. Dispositivos médicos (Decreto 4725 de 2005), todo producto medico requiere una aprobación del INVIMA para asegurar la calidad. Fabricación de armas (Decreto 2535 de 1993 y Ley 1801 de 2016), uso de armas y requisitos para portar una. Protección del consumidor (Ley 1480 de 2011), derechos y protección de los consumidores.

### **Restricciones de Salud y Seguridad**

El uso de este método de fabricación puede conllevar un riesgo en cuanto la exposición a ciertas partículas finas que son liberadas en el proceso de impresión con algunos metales, un ejemplo puede ser el polvo metálico, si se inhala en grandes cantidades y de forma recurrente puede causar enfermedades respiratorias crónicas, Además, algunos materiales plásticos emiten compuestos orgánicos volátiles (COVs) que pueden ser nocivos. (Kwon et al., 2022).

Para mitigar estos riesgos de deben instalar las impresoras en un entorno con suficiente ventilación y extracción para controlar el polvo, aparte de esto los trabajadores deben utilizar equipos de protección y seguir el protocolo de seguridad establecido por la compañía. (Occupational Safety and Health Administration, 2021).

## **Restricciones Socioculturales**

La implementación de esta tecnología puede causar un rechazo tanto en la aceptación como en la adaptación por parte de los trabajadores debido a la automatización del proceso de inspección, esto puede llegar a percibirse como una amenaza a dichos trabajadores, especialmente en países donde la mano de obra no suele estar calificada (García & Pérez, 2022).

## **Metodología**

El proceso comienza descartando todas las soluciones que, aunque parezcan viables en el trasfondo y para el propósito del proyecto no lo son. La compatibilidad con los sistemas presentes, la falta de escalabilidad y los altos costos son criterios a tener en cuenta a la hora de descartar dichas soluciones.

Una vez refinado el conjunto de soluciones potenciales, se procede a una evaluación comparativa basada en hechos conocidos y evidencia empírica documentada en el campo de la visión artificial aplicada a la impresión 3D. Esta etapa se fundamenta en el marco teórico establecido por investigaciones previas, que han demostrado la eficacia de diversas técnicas en la detección de defectos. Por ejemplo, las Redes Neuronales Convolucionales (CNN), cuya efectividad en tareas de reconocimiento de imágenes fue demostrada por Krizhevsky, Sutskever & Hinton (2012), han mostrado una notable capacidad para identificar imperfecciones con alta precisión en piezas impresas en 3D, superando las limitaciones de la inspección manual.

Una vez descartadas dichas posibles soluciones, se hace una evaluación en donde se compararán los hechos y las evidencias que ya existen en el mercado y hayan sido aplicadas, esto se fundamenta principalmente en el marco teórico, por ejemplo, las redes las Redes Neuronales Convolucionales (CNN), cuya efectividad en tareas de reconocimiento de imágenes fue demostrada por Krizhevsky, Sutskever & Hinton (2012) frente a una inspección manual.

A su vez, las Redes Neuronales Siamesas, exploradas por Fierro, Nakano y Yanai (2019) para tareas de recuperación de imágenes, arrojan un potencial significativo al momento de comparar piezas fabricadas con los modelos ideales. Por otro lado, la combinación de Máquinas de Soporte Vectorial (SVM) y técnicas de clustering, como demostraron Singh et al. (2023) en la identificación de defectos internos en piezas de aleación de titanio, da una alta precisión y confiabilidad en la clasificación de distintos tipos de imperfecciones en piezas.

En cuanto a sistemas de detección en tiempo real el método desarrollado por Thomas (2023) en el Laboratorio Nacional Lawrence Livermore, demuestran que efectivamente es posible implementar inspecciones y permite correcciones inmediatas durante el proceso de fabricación. Esto junto a los hallazgos de Ren et al. (2022), cuyo estudio comparativo evidenció la superioridad de los sistemas de visión artificial en términos de precisión, eficiencia y costos operativos si los comparamos con los manuales.

Finalmente, la evaluación principalmente se centra en la precisión, pero no solo en términos de la capacidad que se tiene para identificar las fallas, sino que se necesita minimizar la aparición de falsos positivos, un falso positivo quiere decir cuando arroja un error en alguna de las etapas de fabricación cuando en realidad no hay fallo alguno.

La adaptabilidad de la solución para trabajar con diversos materiales y geometrías de impresión 3D es crucial, así como su capacidad de integración con los sistemas existentes sin causar interrupciones significativas en la producción. Los aspectos económicos, incluyendo los costos iniciales de implementación y los proyectados a largo plazo, se analizan en conjunto con el potencial de retorno de inversión, considerando los hallazgos de Instrumental (2020) sobre la reducción de costos asociados con la inspección y corrección de defectos mediante sistemas automatizados.

Algunos aspectos también a tener en cuenta incluyen la adaptabilidad a distintos entornos y volúmenes de trabajos, costos de implementación, cumplimientos normativos según el país y la usabilidad del sistema,

Esta metodología nos permite tener una solución multifacética teniendo en cuenta todos los factores que puede conllevar implementar este sistema. Al integrar temas como técnicas,

economía, medio ambiente y consecuencias operativas, se establece un marco robusto para la toma de decisión y así dar una solución equilibrada para la fabricación de piezas en 3D.

### Cronograma

Fase	Duración (días)	Descripción	Materiales	Entregable
Revisión de Literatura	7	Investigación y análisis de estudios sobre visión artificial y defectos en impresión 3D.	Artículos académicos, libros, bases de datos	Resumen de la literatura y base teórica del proyecto
Diseño del Sistema	7	Definir la arquitectura del sistema y seleccionar los componentes de hardware y software.	Diagrama de flujo, esquemas de arquitectura	Documento de diseño del sistema
Preparación de Datos	14	Captura, preprocesamiento y etiquetado de imágenes para entrenamiento de modelos.	Cámara de alta resolución, software de etiquetado de datos	Conjunto de datos anotado y preprocesado
Entrenamiento del Modelo	12	Entrenamiento inicial del modelo de detección de defectos, ajuste de	GPU para procesamiento, frameworks como TensorFlow/PyTorch	Modelo entrenado y resultados de evaluación

		hiperparámetros y pruebas.		
Optimización del Modelo	5	Mejora de precisión y eficiencia en la detección, pruebas adicionales en condiciones de producción.	GPU, herramientas de evaluación de rendimiento	Resultados de optimización del modelo
Integración y Pruebas	9	Integración del sistema en el entorno de producción y pruebas en tiempo real.	Impresora 3D, interfaz de usuario	Sistema integrado y funcionando en entorno controlado
Documentación y Presentación	6	preparación de la presentación del proyecto.	Software de presentación	presentación final

### Análisis de costos

#### Costos directos

Se incluyen temas como equipos, software, licencias, instalación y mano de obra

Equipos:

Cámara con enlace a Windows	Entre 1,200,000 hasta 6,000,000
GPU RTX 3060	Entre 1,000,000 hasta 2,000,000
Impresora 3D Bambu Lab X1	Entre 1,200,000 hasta 1,800,000
Sensor de temperatura DHT22	Entre 18,000 hasta 25,000

## Software

TensorFlow, OpenCV, Anaconda	Uso gratuito
Laabelmg, Visual Studio, PyQt5	Depende de la versión, pero suele ser gratuito
API de Telegram	Si se escala tiene costo

## Instalación

Infraestructura de conexión	Dependiendo del volumen de producción entre 200,000 hasta 2,000,000
Instalación	Si se subcontrata podría estar entre 500,000 hasta 1,300,000

## Mano de obra directa

El costo puede variar dependiendo de tiempo para el desarrollo y los ingenieros a cargo, entre 1,300,000 hasta 7,800,000
--

**Costos indirectos**

## Permisos y licencias

Registro mercantil	Entre 200,000 hasta 1,000,000
Licencia de funcionamiento	Entre 100,000 hasta 500,000
Patentes	Entre 1,000,000 hasta 5,000,000
Licencia para comercialización	Suele estar en 500,000

**Capital de trabajo**

Materias primas	Depende el material usado, pero para hacer pruebas un filamento suele estar entre 70,000 hasta 120,000
Otros costos operativos	Electricidad, mantenimiento, transporte

## Análisis de resultados

Los resultados obtenidos en este proyecto destacan por un excelente desempeño en términos de precisión, alcanzando un 97.3%. Esto indica que el modelo tiene una gran capacidad para clasificar correctamente las predicciones realizadas, minimizando falsos positivos y logrando una alta confiabilidad en las detecciones confirmadas. No obstante, el Recall, con un valor del 50%, señala que el modelo logra identificar solo la mitad de los objetos relevantes presentes en las pruebas, lo que pone de manifiesto una limitación en su capacidad para detectar todos los casos esperados. Este comportamiento puede atribuirse a factores como la insuficiencia o el desequilibrio en las clases del conjunto de datos utilizados durante el entrenamiento. Sin embargo, en el contexto del procesamiento de videos, esta limitación se ve mitigada, ya que el flujo continuo de cuadros permite que los objetos no detectados en uno de ellos puedan ser identificados en cuadros posteriores, equilibrando así el impacto de un Recall moderado en aplicaciones prácticas.

Por otro lado, el valor de mAP obtenido, de 47%, refleja un desempeño general que combina tanto precisión como sensibilidad, posicionando al modelo en un nivel funcional pero con margen para mayor optimización. El mAP evalúa el equilibrio entre la capacidad del modelo para evitar falsos positivos y su habilidad para detectar los casos relevantes en un rango de diferentes umbrales. En este caso, el alto valor de precisión eleva considerablemente el rendimiento, pero el Recall más bajo limita el puntaje general, indicando que el modelo es más preciso que completo en términos de detección. A pesar de esto, el diseño para trabajar con videos lo hace viable y funcional, ya que las características secuenciales del medio proporcionan una oportunidad para corregir las detecciones incompletas en cuadros individuales.

## Conclusiones

Tras atravesar las etapas de desarrollo, se logró cumplir con los objetivos planteados, llevando a cabo la implementación de un sistema de visión artificial para la detección de defectos en piezas impresas en 3D. Primero, se evaluaron las distintas técnicas y algoritmos de visión artificial, seleccionando los más adecuados en el contexto para detectar defectos como porosidades, deformaciones y falta de adhesión entre capas, logrando una precisión que por el método manual no sería posible. Luego, se procedió a diseñar la arquitectura del sistema, asegurando que fuera capaz de operar de forma autónoma, desde la etapa de captura de imágenes hasta la interpretación de los defectos en tiempo real. Finalmente, se analizó el desempeño del sistema, demostrando que no solo es preciso, sino también escalable, lo que permite adaptarse a diferentes volúmenes de fabricación.

Este sistema como ya lo vimos mejora la eficiencia y precisión del proceso de inspección, también elimina los errores humanos que se ven relacionados con la inspección manual. Este avance ayuda a reducir los costos de fabricación y los tiempos de entrega, ya que se minimizan las re- fabricaciones y correcciones de piezas defectuosas. Al lograr estos objetivos, el proyecto ha demostrado cómo la visión artificial puede transformar el proceso de fabricación en la impresión 3D, haciendo que las empresas puedan asegurar una calidad en la fabricación sin tener que invertir una cantidad importante de dinero.

## Referencias

1. Bordekar, H., Cersullo, N., Brysch, M., Philipp, J., & Hühne, C. (2023). "eXplainable artificial intelligence for automatic defect detection in additively manufactured parts using CT scan analysis." ("eXplainable artificial intelligence for automatic defect detection in ...") *Journal of Intelligent Manufacturing*. <https://doi.org/10.1007/s10845-023-02272-4>
2. Singh, S. A., & Desai, K. A. (ca). Automated surface defect detection framework using machine vision and convolutional neural networks. *Journal of Intelligent Manufacturing*. <https://doi.org/10.1007/s10845-021-01878-w>
3. Zhao, X., Li, Q., Xiao, M. et al. Defect detection of 3D printing surface based on geometric local domain features. *Int J Adv Manuf Technol* 125, 183–194 (2023). <https://doi.org/10.1007/s00170-022-10662-w>
4. Zhang, H., Zong, Z., Yao, Y. et al. Multi-Axis 3D Printing Defect Detecting by Machine Vision with Convolutional Neural Networks. *Exp Tech* 47, 619–631 (2023). <https://doi.org/10.1007/s40799-022-00577-2>
5. Jeremy Thomas. (2023). Method for real-time defect detection in metal 3D-printed parts. Lawrence Livermore National Laboratory. Recuperado de <https://www.llnl.gov/news/method-real-time-defect-detection-metal-3d-printed-parts>
6. Instrumental. (2020). Manual Inspection vs. AI Inspection with Instrumental.
7. Ren, Z., Fang, F., Yan, N., & Wu, Y. (2022). State of the Art in Defect Detection Based on Machine Vision. *International Journal of Precision Engineering and Manufacturing-Green*
8. Gibson, I., Rosen, D., & Stucker, B. (2015). *Additive Manufacturing Technologies* (2nd ed.). Springer. <https://doi.org/10.1007/978-1-4939-2113-3>
9. Lopez-Carreño, J., Calvo-Lavado, C., & Zarate-Perez, E. (2023). Performance of Image Recognition with Machine Vision: A Systematic Review. *Ingeniería*, 28(1), e18934. [https://laccei.org/LACCEI2023-BuenosAires/papers/Contribution\\_839\\_a.pdf](https://laccei.org/LACCEI2023-BuenosAires/papers/Contribution_839_a.pdf)
11. Serna, E., Martínez, R., & Tamayo, P. (2019). Una revisión a la realidad de la automatización de las pruebas del software. *Computación y Sistemas*, 23(1), 169-182. <https://doi.org/10.13053/cys-23-1-2782>.
12. Hurtado-Cortés, L. L., Villarreal-López, E., & Villarreal-López, L. (2016). Detección y diagnóstico de fallas mediante técnicas de inteligencia artificial, un estado del arte. *DYNA*, 83(199), 58-67. <http://dx.doi.org/10.15446/dyna.v83n199.55612>
13. Wohlers, T., & Caffrey, T. (2014). *Wohlers Report 2014: 3D Printing and Additive Manufacturing State of the Industry Annual Worldwide Progress Report*. Wohlers Associates.

14. Thompson, M. K., & Thompson, J. Y. (2016). *Additive Manufacturing: Modeling Systems and 3D Printing*. Springer.
15. Wang, X. (2017). Quality control in additive manufacturing: Challenges and opportunities. *Journal of Manufacturing Science and Engineering*, 139(10), 100905
16. Fierro, A. N., Nakano, M., & Yanai, K. (2019). Redes Convolucionales Siamesas y Tripletas para la Recuperación de Imágenes Similares en Contenido. *Información tecnológica*, 30(6)
17. Ultatek. (2024). *Sistemas de inspección y control de la calidad automatizados para procesos de manufactura*. Ultatek.
18. Comisión Europea (2020). *Reglamento General de Seguridad de Productos*.
19. García, L., & Pérez, M. (2022). "Desafíos de la digitalización en el mercado laboral."
20. Gómez, R., & Sánchez, D. (2021). "Aspectos legales en la impresión 3D."
21. Johnson, T. (2023). "Economic Barriers in Adopting Additive Manufacturing."
22. Kwon, J., et al. (2022). "Health Risks Associated with 3D Printing."
23. López, P., & Fernández, A. (2022). "Subvenciones y ayudas para la transformación digital de pymes."
24. McAlister, S., & Smith, R. (2022). "Environmental Impacts of 3D Printing."
25. Miller, T., et al. (2021). "Circular Economy Approaches in Additive Manufacturing."
26. Occupational Safety and Health Administration (2021). "Guidelines for Safe 3D Printing."

27. Ren, J., et al. (2022). "Artificial Vision Systems in Manufacturing."
28. Rodríguez, A., & Valenzuela, G. (2022). "Integración tecnológica y capacitación laboral."
29. Singh, N., & Desai, P. (2023). "Machine Learning in Defect Detection."
30. Watson, D. (2022). "Cost-Benefit Analysis of Automated Quality Control."
- 31.nex. (2024). Aspectos básicos de la visión artificial: definiciones, usos y beneficios. Cognex.  
<https://www.cognex.com>
- 32.IBM. (2024). ¿Qué es el aprendizaje profundo?. IBM. <https://www.ibm.com>
- 33.NVIDIA Developer. (2024). Deep Learning Frameworks. NVIDIA Developer.  
<https://developer.nvidia.com/deep-learning-frameworks>
- 34.Geekflare. (2024). 11 Software de aprendizaje profundo en 2024. Geekflare. <https://geekflare.com>
- 35.SciELO. (2021). Imagen y poder en la era de la visión artificial. SciELO. <https://scielo.org>
- 36.SciELO. (2022). El aprendizaje profundo como herramienta para cambio en la visión de aprendizaje de una cultura escolar. SciELO. <https://scielo.org>
- 37.Springer. (2021). HGP4CNN: un framework eficiente de paralelización para el entrenamiento de redes neuronales convolucionales en GPUs modernas. Springer. <https://springer.com>
- 38.SciELO. (2013). Los enfoques de aprendizaje. SciELO. <https://scielo.org>

39. Cubides-Garzón, J. R., Rocha-Herrera, Y. P., Picón-Jaimes, A. J., y Rojas-Ortiz, M. Y. (2024). Systematized review of artificial intelligence applied to digital marketing in Colombia. *Visión electrónica*, 18(1). <https://revistas.udistrital.edu.co/index.php/visele/article/view/22414>
40. Junwei, Y. (2022). Detección de fallos de impresión 3D por medio de visión artificial
41. Krizhevsky, Alex & Sutskever, Ilya & Hinton, Geoffrey. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Neural Information Processing Systems*. 25. 10.1145/3065386.